第65卷 第2期 天 文 学 报 Vol. 65 No. 2
2024年3月 ACTA ASTRONOMICA SINICA Mar., 2024

doi: 10.15940/j.cnki.0001-5245.2024.02.006

一种低表面亮度星系的自动搜索算法—YOLOX-CS*

冯雪琦[1‡] 屠良平[1,2†] 仲峥迪[1] 李 娟[1] 李 馨[1]

(1 辽宁科技大学理学院 鞍山 114051)
(2 闽南师范大学数学与统计学院 漳州 363000)

摘要 低表面亮度星系(Low Surface Brightness Galaxy, LSBG)的特征对于理解星系整体特征非常重要, 通过现代的机器学习特别是深度学习算法来搜寻扩充低表面亮度星系样本具有重要意义. LSBG因特征不明显而难以用传统方法进行自动和准确辨别, 但深度学习确具有自动找出复杂且有效特征的优势, 针对此问题提出了一种可用于在大样本巡天观测项目中搜寻LSBG的算法—YOLOX-CS (You Only Look Once version X-CS). 首先通过实验对比5种经典目标检测算法并选择较优的YOLOX算法作为基础算法, 然后结合不同注意力机制和不同优化器, 构建了YOLOX-CS的框架结构. 数据集使用的是斯隆数字化巡天(Sloan Digital Sky Survey, SDSS)中的图像, 其标签来自于α.40-SDSS DR7 (40%中性氢首蓿巡天与第7次数据发布的斯隆数字化巡天的交叉覆盖天区)巡天项目中的LSBG, 由于该数据集样本较少, 还采用了深度卷积生成对抗网络(Deep Convolutional Generative Adversarial Networks, DCGAN)模型扩充了实验测试数据. 通过与一系列目标检测算法对比后, YOLOX-CS在扩充前后两个数据集中搜索LSBG的召回率和AP (Average Precision)值都有较好的测试结果, 其在未扩充数据集的测试集中的召回率达到97.75%, AP值达到97.83%, 在DCGAN模型扩充的数据集中, 同样测试集下进行实验的召回率达到99.10%, AP值达到98.94%, 验证了该算法在LSBG搜索中具有优秀的性能. 最后, 将该算法应用到SDSS部分测光数据上, 搜寻得到了765个LSBG候选体.

关键词 星系: 普通, 方法: 数据分析, 方法: 目标检测, 技术: 图像处理
中图分类号: P152; **文献标识码**: A

1 引言

低表面亮度星系(Low Surface Brightness Galaxy, LSBG)相较于正常星系单位面积所发出的光较少, 与灰暗的天空背景差异不大的表面亮度使天文学家们忽略了对低表面亮度星系的发现与研究, 因此在很长一段时间内学者们低估了它们对整个宇宙星系星族的贡献. 随着CCD (Charge-coupled Device)深场探测及现代数字巡天的开展、科学技术的不断进步, 天文学家对低表面亮度星系的光学、近红外、紫外及射电等波段进行了深入的观测研究. 至今天文学家们已经观测到了一些不同类型和不同形态的低表面亮度星系并公布了它们的星表, 进一步研究发现它们对于天文学研究具有重要的促进作用, 同时LSBG的特征也对理解星系整体特征非常重要[1]. 所以有必要搜寻更多的新

2022-12-15收到原稿, 2023-03-14收到修改稿
*国家自然科学基金项目(U1731128)资助
†tuliangping@ustl.edu.cn
‡1556164886@qq.com

的LSBG样本供天文学家深入研究.

Zwicky[2]于1957年首次提出存在低表面亮度星系, 并定义其是比黑暗夜空更暗的星系. Freeman[3]于1970年第1次发现低表面亮度星系, 他在研究时发现有28个盘星系B波段中心面亮度在(21.65 ± 0.3) mag · arcsec^{-2}的范围内, 此后该规则被称为Freeman规则. McGaugh[4]于1996年详细地划分了低表面亮度星系的B波段中心面亮度的取值范围, 认为取值在22.75–24.5 mag · arcsec^{-2}之间的星系为低表面亮度星系. Impey和Bothun[5]则选择定义低表面亮度星系是B波段中心面亮度比23.0 mag·arcsec^{-2}更暗的星系. 而Impey等[6]和Ceccarelli等[7]所设置的阈值在22.0–23.0 mag · arcsec^{-2}的范围内. 对于低表面亮度星系通常是通过B波段的中心面亮度低于某个阈值来定义的, 该阈值通常在21.5–24.5 mag · arcsec^{-2}的范围内, 但如今此阈值也没有统一的标准. 除B波段外, r/R波段[8–9]和Ks波段[10]也可以用于定义LSBG.

继Freeman[3]第1次找到低表面亮度星系以来, 越来越多的中心面亮度较低的低表面亮度星系逐渐被发现. 1996年, Impey等[11]在近域宇宙的巡天项目中发现了693个低表面亮度星系. 1999年, Bergvall等[12]基于红外J、H、K波段面源测光发现14个蓝色低表面亮度星系. 2000年, Bell等[13]对26个低表面亮度星系在光学和近外方向进行了深度成像的研究. 1996年, Jong[14]发现螺旋星系中的低表面亮度星系并研究了此螺旋星系特性之间的关联. 2002年, Galaz等[15]在Impey等[11]的星表中取出88个星系的J和Ks波段近红外成像数据并研究样本特性的相关性. 2004年, Kniazev等[16]研究了一种算法来试图从斯隆数字化巡天(Sloan Digital Sky Survey, SDSS)观测图像中搜寻LSBG, 其使用的测试样本为Impey等[11]星表中与EDR (Early Data Release)重叠的子样本, 并用APM (Astronomical Plate Measuring)样本检验其算法, 最终得到的检测率为96.5%, 并发现了42个新低表面亮度星系. 在1997年O'Neil等[17]在巨蟹座、飞马座星系团和巨壁定义的低密度区域中发现129个偏红低表面亮度星系样本. 2003年Ragaigne等[18]从2MASS (Two Micron All Sky Survey)中选择了一个更大的样本约3800个红外低表面亮度星系, 并表明在这些星系中没有明显的红色星系群. 2008年Zhong等[19]在SDSS-DR4 (Data Release 4)主星系样本中发现了12282个近正向低表面亮度星系大样本并展示了这些样本B波段的中心面亮度、标长、累积星等、颜色和距离.

随着巡天项目的不断开展, 近几十年来已经确定了大量的LSBG样本. 2011年, 苜蓿巡天(Arecibo Legacy Fast ALFA Survey, ALFALFA)项目提供了一个河外HI线源40%的星表(α.40星表)[20]. 该星表适用于寻找LSBG, 因为LSBG被认为含有丰富HI气体. 利用α.40星表, 2015年Du等[21]发现了1129个LSBG, 它们都是非侧向星系, 本文所利用的数据集即为这些样本. 2018年, Greco等[22]提供了781个低表面亮度星系的候选星表, 这781个低表面亮度星系的颜色跨越红色$g-i \geqslant 0.64$及蓝色$g-i < 0.64$ ($g-i$表示g波段星等值减去i波段星等值的差)并表明低表面亮度星系的表面亮度分布受颜色的影响较大. 2021年, Tanoglidis等[23]提供了来自于暗能量巡天的23790个扩展的低表面亮度星系的候选星表. 本文选取其中一部分最终验证算法的性能.

现如今深度学习的发展迅速, 各个领域都进入大数据时代, 天文领域也不例外, 尤其是将深度学习应用于海量天文观测数据的分类研究中, 表现出较为理想的效果. 但将目标检测应用于寻找低表面亮度星系还比较少, 2021年, Tanoglidis等[24]使用卷积神经网络Mask R-CNN (Region-based Convolutional Neural Networks)检测和掩膜光学巡天图像中的伪影和散射光伪影, 表现出不错的效果. 2022年Yi等[25]将目标检测算法运用于检测低表面亮度星系并取得了不错的效果, 其实验的召回率达到95.75%.

当前目标检测算法主要分为两大类型, 一种为一阶段, 一阶段目标检测算法不需要产生候选框, 其中最具代表性的为YOLO (You Only Look Once)系列算法模型; 另一种为二阶段, 二阶段是先由算法生成候选框, 再对样本进行分类, 其中最具代表性的为Faster R-CNN[26]算法模型. 目标检测算法自2014年以来的主要发展历程如图1所示.

本文的目的是研究高效的目标检测算法来搜寻相对不容易被发现的低表面亮度星系. 流程如图2所示, 具体步骤如下:

(1)通过低表面亮度星系星表在SDSS DR16官网下载对应的测光图像, DR16官网网址为: https://data.sdss.org/sas/dr16/;

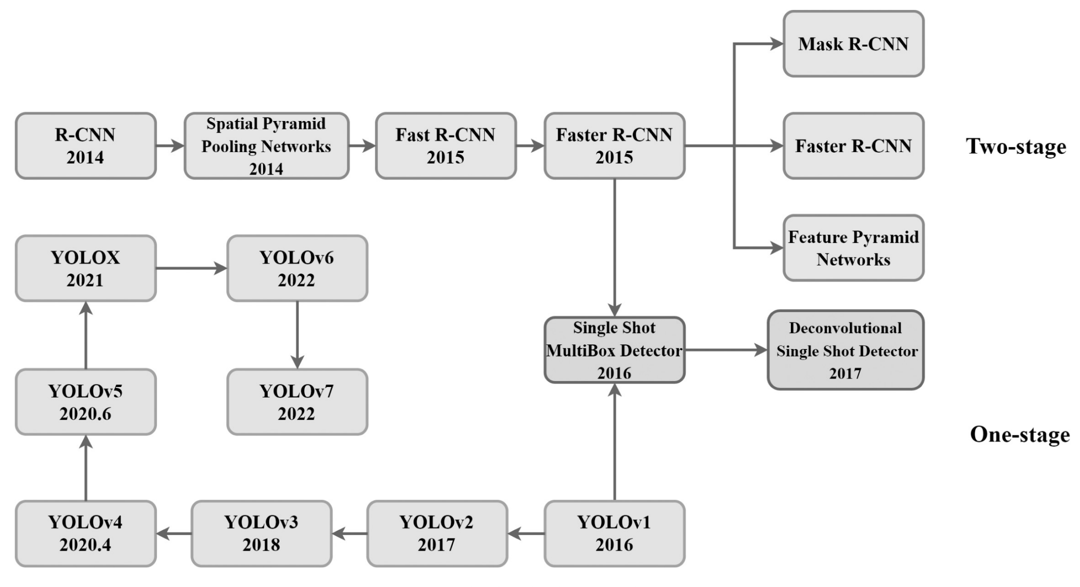


图 1　目标检测算法的主要发展历程

Fig. 1　Main important development of target detection algorithm

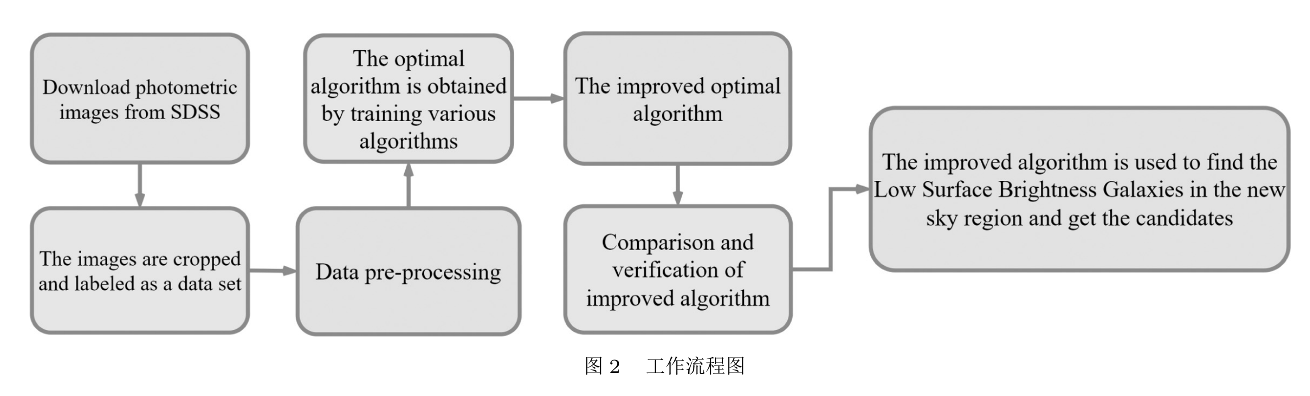


图 2　工作流程图

Fig. 2　Workflow chart

(2)下载得到官方g、r、i伪彩图及g、r、i波段的灵活图像传输系统(Flexible Image Transport System, FITS)格式文件, 运用Python程序将低表面亮度星系的赤经和赤纬转换为像素坐标标注出图像中的低表面亮度星系并裁剪, 再运用图形图像注释工具labelImg对裁剪后的图像进行标注并保存为VOC (Visual Object Classes)格式. 最后将裁剪标注后的低表面亮度星系按约8:2的比例划分为训练集和测试集. 同时利用深度卷积生成对抗网络(Deep Convolutional Generative Adversarial Networks, DCGAN)扩充数据集作为待使用的第2个数据集;

(3)对要输入进行训练的图像进行Mosaic (4张不同的图像经处理变换后拼接成一张图像)数据增

强和随机缩放、宽高比调整等数据预处理. 接下来运用不同的目标检测算法对低表面亮度星系进行识别, 并选出检测效果最优的算法即YOLOX (You Only Look Once X);

(4)通过预训练、改变优化器和加入不同的注意力机制模块、扩充数据集等一系列的操作, 提出了适用于搜寻低表面亮度星系的YOLOX-CS (You Only Look Once version X-CS)算法, 并将算法应用于其他数据集中进行验证;

(5)利用算法在SDSS发布的3615及3647两个天区测光数据中共找到765个低表面亮度星系候选体.

本文写作结构如下: 第2节介绍了本文数据的选取、数据集的划分及图像预处理; 第3节说明YOLOX算法的选择实验理由以及YOLOX的改进; 第4节重点进行了实验结果分析, 包括算法评估指标、实验参数设置、实验环境、5种经典目标检测算法实验结果、改进算法实验结果及其验证; 最后在第5节将本文算法应用在SDSS部分天区得到了一部分新的低表面亮度星系候选体.

2 数据

SDSS DR16[27]记录了阿帕奇天文台星系演化实验2 (Apache Point Observatory Galactic Evolution Experiment-2, APOGEE-2)和扩展重子振荡光谱巡天(Extended Baryon Oscillation Spectroscopic Survey, eBOSS)的数据发布. eBOSS发布了860935个星系和类星体的新光谱, APOGEE-2包括了751864个新的红外光谱. 由于SDSS数据的发布是累积的, DR16包括了所有曾发布过的数据.

本节主要介绍数据的选取, 数据集的制作、扩充与划分, 数据增强及图像预处理.

2.1 数据准备

SDSS官方可以获取的数据为u、g、r、i、z波段的数据, 但u、z波段包含的有用信息非常少, 多为近紫外和近红外, 故本文选取g、r、i波段数据合成的图像和FITS文件. 在文献[21]中得到低表面亮度星系星表, 此星表是在40%的ALFALFA天空区域与SDSS DR7交叉共享覆盖区即α.40-SDSS DR7中搜寻得到, 通过星表中的赤经和赤纬在SDSS DR7网站中来搜索到相对应的FITS文件, 对g、r、i波段的FITS文件进行先转彩色图像再转灰度图像, 最后合成三通道图像. 由于DR7官方的像素值为0–65535, 而低表面亮度星系的像素值偏低, 故这样获得的图像丢失掉很多低表面亮度星系的特征信息. 考虑到DR16和DR7, 它们的原始数据是一样的, 只是对原始数据进行处理的软件版本不同, DR16使用的数据处理软件版本是目前为止最稳定的, 最终以DR16数据为准. 数据的文件名由run、camcol、field、filter这4个字段构成, 例如: DR7文件名为fpC-run-filter-camcol-field.fit.gz; DR16文件名为frame-filter-run-camcol-field.fits.bz2. 所以通过DR7中的run、camcol及field可以在DR16找到相同的最新处理的数据, 通过这种方式找到了1106张g、r、i波段官方合成的图像以及g、r、i波段的FITS文件. 三波段图像同样可以使用文献[28]中的方法进行合成. 通过对比, 官方合成图像更能体现出低表面亮度星系的特征信息, 而且官方证实伪彩图的效果与真实的色彩十分接近, 故最终本文直接将官方伪彩图作为数据集.

2.2 图像预处理及数据集的划分

在SDSS DR16官方网站上所下载的天文图像像素大小为2048 × 1489. 为了更清晰地展示其形态, 图3展示了12个低表面亮度星系的示例, 图片来自于SDSS官网(网址: http://skyserver.sdss.org/dr16/en/tools/chart/navi.aspx)目标天体的预览图像, 其中E、N、W、S是指东、北、西、南4个方向. 这12个目标天体的原天文图像由左向右、由上向下依次为:
frame-irg-001035-2-0045; frame-irg-002126-2-0436; frame-irg-002126-4-0429; frame-irg-002126-6-0410; frame-irg-002391-5-0050; frame-irg-002566-3-0297; frame-irg-003015-6-0218; frame-irg-003525-4-0136; frame-irg-003631-6-0344; frame-irg-003836-4-0443; frame-irg-003841-3-0076; frame-irg-004649-5-0190.

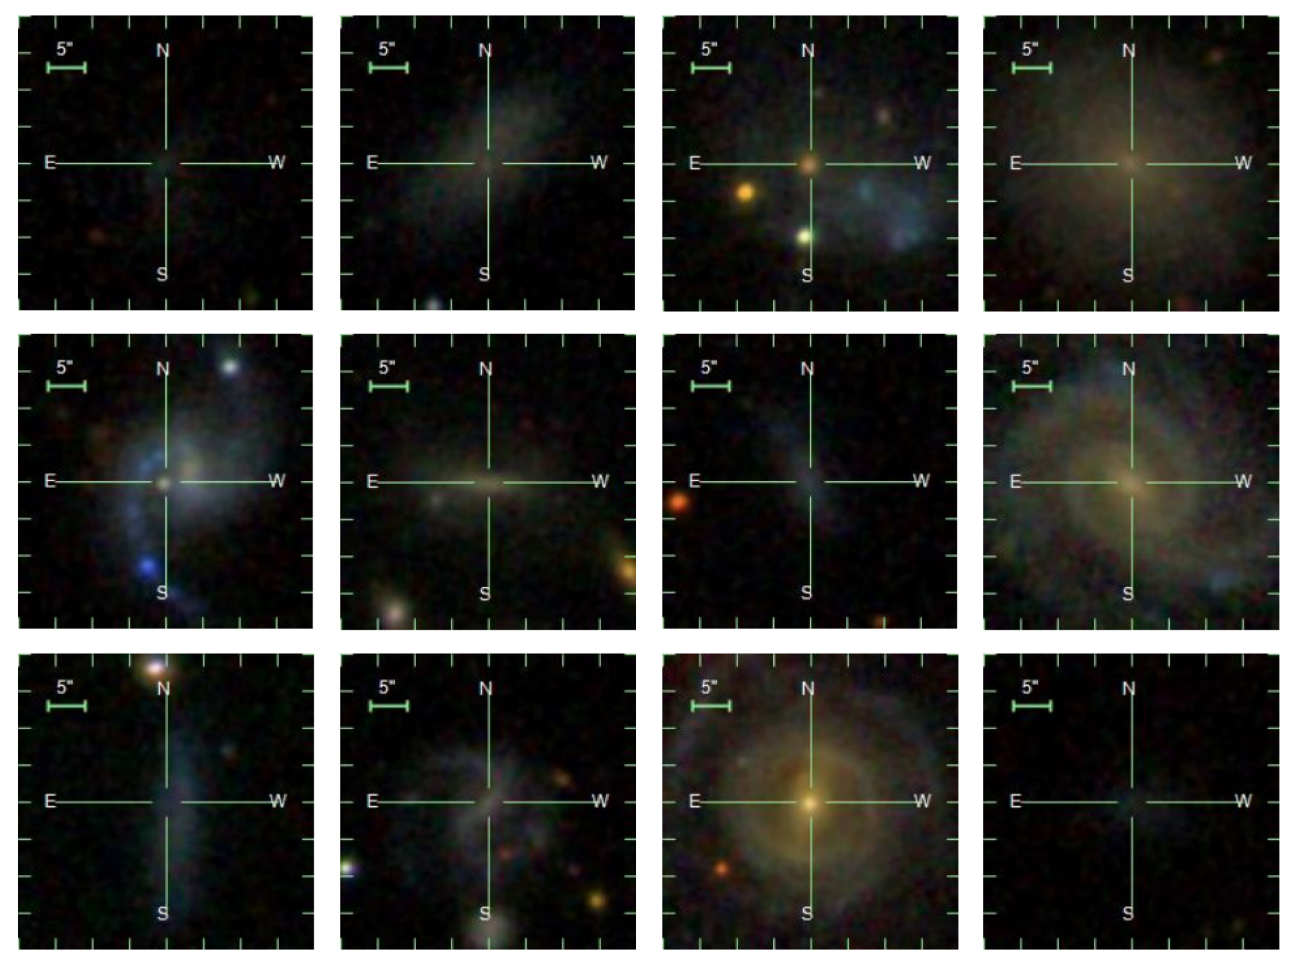


图 3　低表面亮度星系图像示例

Fig. 3　Examples of Low Surface Brightness Galaxy image

本文将图像根据目标所在位置裁剪为640 × 640和600 × 600两种尺寸大小分别适用于YOLO系列算法、CenterNet[29]和Faster R-CNN[26]算法, 这样做不仅能够让图像大小适应算法要求, 而且能提高算法的特征提取能力. 首先通过将目标的赤经和赤纬信息转换为测光图像中的像素坐标, 从而得知目标中心点, 根据目标中心点再将图像裁剪为640 × 640和600 × 600两种像素大小. 其次, 根据目标中心点像素标出目标中心位置. 第三, 根据标出的目标中心位置对裁剪好的图像进行标注获得最终的数据集, 其中包含所有训练样本及标注的xml文件. 由于本文数据集较小, 所有的样本被随机划分为两个部分, 训练集与测试集比例约为8:2, 即训练集中含有884个样本, 测试集中含有222个样本.

由于数据集较小, 本文使用DCGAN[30]模型进行数据集的扩充. 通过统计数据集中的1106张图像, 只有49张超过96 × 96像素. 而超过96 × 96像素目标的特征也能够体现在96 × 96像素的图像中. 故本文先根据目标中心点将图像裁剪为96 × 96像素大小, 然后使用DCGAN模型训练生成新的样本. 在2000轮次的训练学习中, 本文选取了效果最好轮次的图片. 共选取了1000个目标的40张图片(每张图片包含25个目标), 图片像素大小为640 × 640, 图4展示了其中两张图片. 将它们放入数据集以增加训练模型的特征提取能力, 这样数据集共1146张图片, 包括2106个标注的目标. 此数据集中所有的

样本按照约8:2的比例随机划分为训练集和训练验证集, 即训练集中含有917个样本, 训练验证集中含有229个样本. 测试集和第1个数据集中的测试集一样.

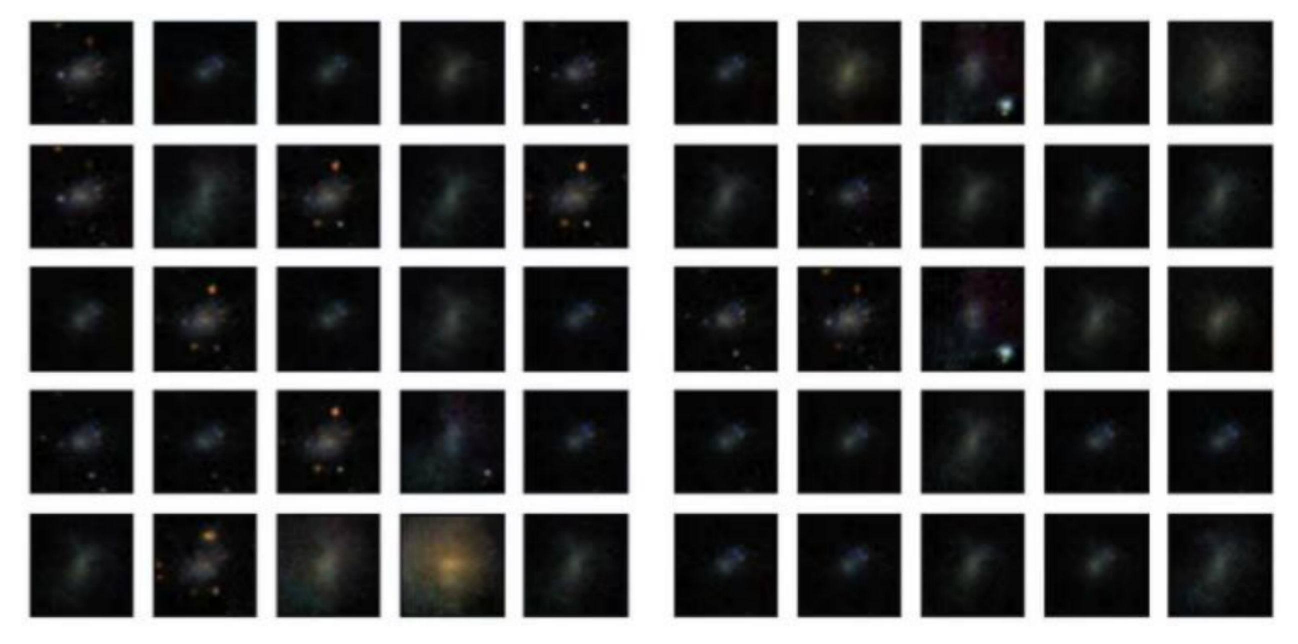


图 4　DCGAN生成的图像(每个小图都是单目标源合成图像)

Fig. 4　Images generated by DCGAN (each small image is a composite image of a single target source)

本文使用Mosaic数据增强方法来提高数据的多样性. 在每一批次训练前使用此方法进行数据增强, Mosaic抽取训练集中的4张图片进行随机大小缩放、色域变换、水平翻转, 然后将经过变换后的4张图片拼接在一起形成一张初始数据集中没有的图片输入模型进行训练. 每一次训练图片的大小、颜色都与之前不同, 极大降低了反复训练相同图片过拟合的可能. 在增强图像时目标框的位置也会随着图像的改变而改变. 图5为经过Mosaic数据增强后的图片.

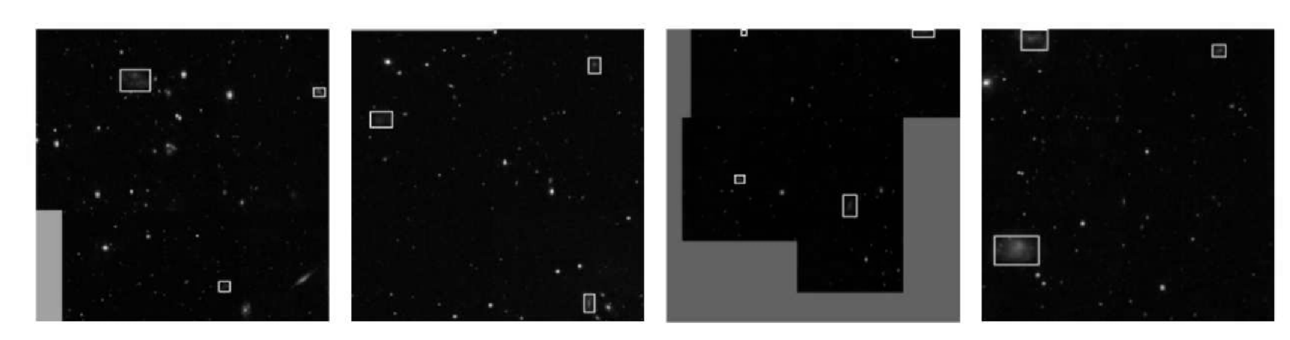


图 5　经过Mosaic数据增强后的图片

Fig. 5　Images enhanced by Mosaic data

为了提高算法的泛化能力, 本文对训练集样本进行了预处理(图6为其中一个样本预处理后图片的示例), 步骤如下: 先在(0.25, 2)之间随机缩放, 然后在(0.5, 1.9)之间随机扭曲宽高比, 这些步骤皆不会改变源的类型.

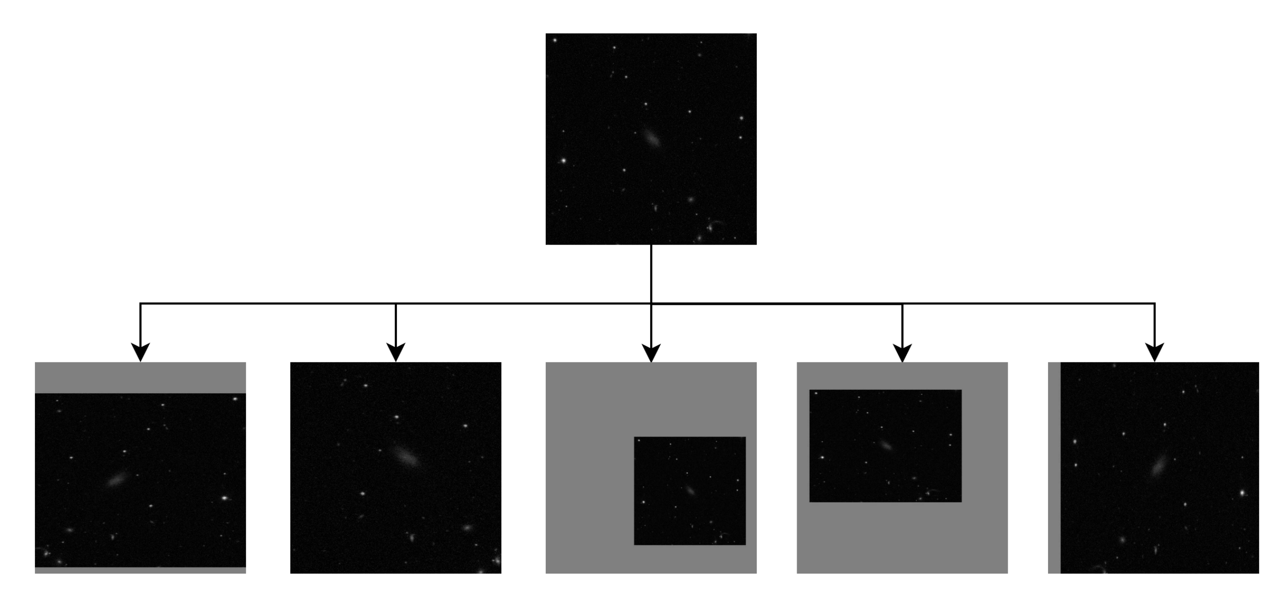


图 6　将frame-irg-002126-2-0436根据目标所在位置裁剪为640 × 640像素之后进行预处理得到的图像

Fig. 6　Preprocessed frame-irg-002126-2-0436 image after cropping to 640 × 640 pixels according to the location of the target

3　算法

3.1　YOLOX

YOLOX是Ge等[31]提出的单阶段目标检测算法. 其主要分为3个部分, 主干网络为CSPDarknet (Cross Stage Partial Darknet), 中间部分为特征金字塔网络, 最终部分为YOLO Head. CSPDarknet内部的主要特征提取利用残差结构和CSPNet (Cross Stage Partial Network)结构[32], 并在其中使用了在YOLOv5 (https://github.com/ultralytics-/yolov5)中用到的Focus结构, 可以有效减小参数量, 提升网络计算速度. 图7为CSPNet和YOLO Head的结构图, 其中, CBS由卷积、批量标准化(Batch Normalization, BN)和SiLU (Sigmoid-weighted Linear Unit)激活函数组成, Res Unit为残差单元, Concat是对不同分支的特征进行拼接; Reg、Cls、Obj为3个预测结果. CSPNet结构如图7左边所示, 分为两个部分, 一部分在卷积操作后继续残差单元的堆叠即进一步的特征提取, 而另一部分只经卷积操作少量处理, 之后将两部分拼接进行特征融合, 这种网络结构可以充分利用不同特征层之间的关系, 有效地减少信息丢失和梯度消失的问题, 提升网络的鲁棒性.

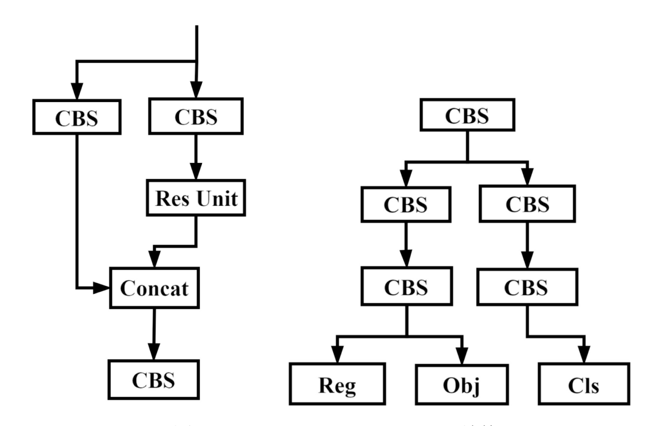


图 7　CSPNet及YOLO Head结构

Fig. 7　CSPNet and YOLO Head structure

CSPDarknet还使用了空间金字塔池化结构(Spatial Pyramid Pooling, SPP)[33], 此结构可以提

升网络的感受野. 最终在此网络结构中获取到3个不同位置的特征层作为有效特征层并输入到下一部分网络中. 中间部分即特征金字塔网络将主干网络中输出的3个特征层进行特征融合, 以获得不同尺度的特征信息. 这一部分依旧沿用路径聚合网络(Path Aggregation Network, PANet)[34]使得3个尺度特征层自上而下和自下而上相互融合从而获取更为丰富的特征. YOLOX的解耦头有所变化, YOLOv4、YOLOv5的YOLO Head所用的分类和回归是在一个1 × 1卷积里实现, YOLOX中YOLO Head的分类和回归被分别实现. 如图7右边所示, 此图中右边为分类, 左边为回归, 在对3个特征层进行卷积操作后得到3个预测结果, Reg是用于判断特征点的回归参数, 调整回归参数后可以获得预测框; Obj用于判断特征点是否包含目标源; Cls用于分类, 判断特征点所包含的目标类型.

YOLOX与之前YOLO系列算法不同之处还有不使用先验框, 所以需要SimOTA (Sim Optimal Transport Assignment)的方法来筛选, SimOTA是OTA (Optimal Transport Assignment)[35]的一个精简提升版本. OTA是可以更好地获得全局最优的标签分配策略.

本文中最终使用YOLOX作为接下来进行改进的目标检测算法, 文中4.3节具体说明了理由.

3.2　改进后的模型架构

YOLOX的CSPDarknet主干部分有多个残差网络, 并且CSP (Cross Stage Partial)层会将输入特征直接与多个残差连接, 这对解决梯度消失的问题有不错的效果, 但将特征信息传输到更深网络的同时也会将噪声一起传输到更深的网络. 为了使这个问题得到一定程度的解决并使得网络更关注待测目标, 忽略不必要的信息, 需要在主干网络的3个特征层后加入注意力机制. 注意力机制能够提升特征抽取的准确性, 针对不同的输入分配不同的权重, 最后输出结果时再赋予合适的权值, 是深度学习过程中模仿人脑的注意力模型. 目前注意力机制主要分为通道注意力机制和空间注意力机制, SE (Squeeze-and-Excitation)[36]和ECA (Efficient Channel Attention)[37]注意力机制为通道注意力机制, CBAM (Convolutional Block Attention Module)[38]和CA (Coordinate Attention)[39]为通道注意力机制和空间注意力机制混合使用. CBAM和CA注意力机制更关注于通道与空间之间的联系, 故加入更能抓住目标特征. 图8为CBAM注意力机制的结构. 图9为改进后的YOLOX模型结构, 其中括号内的数字代表当前层三维像素矩阵的大小, 例如Input (640, 640, 3)为输入具有640个像素高度、640个像素宽度和3个通道的图像. Focus是每隔一个像素取一个值, 从而得到4个独立的特征层, 使得输入通道数扩大了4倍, 由原来的3通道变为12通道, 像素宽高度减半, 即变成了具有12个特征图的特征层, 每个特征图的大小为320 × 320; Conv2D_BN_SiLU由二维卷积、BN和SiLU激活函数构成, 通过滑动卷积核对输入的特征图进行卷积运算, 从而进一步提取特征.

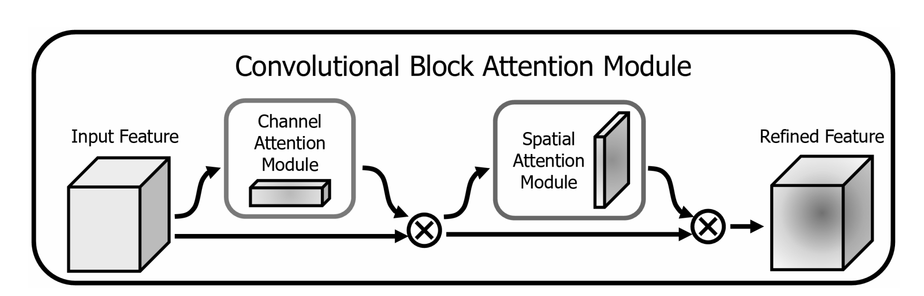


图 8　CBAM注意力机制结构[38]

Fig. 8　Structure of CBAM attention mechanism[38]

在深度学习算法中, 两个主要因素影响模型性能: 模型结构和优化方法. 而其中优化方法会直接影响深度学习算法的速度及性能, 因此研究能够改进深度学习算法性能的优化策略是有必要的. 目前大多数的优化算法都是迭代实现的, 随机梯度下降(Stochastic Gradient Descent, SGD)、SGDM (Stochastic Gradient Descent with Momentum)、自适应学习率的梯度下降算法(Adaptive Gradient, AdaGrad)、均方根传递(Root Mean Square Prop, RMSprop)和Adam (Adaptive moment estimation)为现阶段常用的深度学习优化器. SGD是目前神经网络最基础的迭代算法. SGDM是在SGD的基础上增加了一阶动量; Adagrad和RMSprop都是在SGD的基础上增加了二阶动量; Adam是结合SGDM的一阶动量和RMSprop的二阶动量的算法. 文献[40]中的结果表明Adam具有较好的优化效果, SGD耗时较久, 但其训练过程中损失值下降速度最快. 故最终选择SGD、RMSprop和Adam这3个优化器进行实验.

4　实验结果与分析

4.1　算法评估指标

本文选择通用的准确率、召回率、F1值和AP (Average Precision)值作为检测低表面亮度星系的算法的评价指标(见表1). TP值为与Ground truth区域的IOU (Intersection Over Union)大于等于0.5所得到的值, FP值为IOU小于0.5所得到的值. 各指标计算公式如下: 准确率表示在样本中预测正确的比率:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}. \tag{1}$$

表 1　评价指标
Table 1　Evaluation indicator

Forecast	Real LSBG	Unreal LSBG
Right prediction	True Positive (TP)	False Positive (FP)
Wrong prediction	False Negative (FN)	True Negative (TN)

召回率表示在样本中实际正确的比率:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}. \tag{2}$$

F1值通过准确率和召回率计算得到:

$$\text{F1} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}. \tag{3}$$

AP值表示在不同召回率点上对应的准确率的平均值, 也可以表示为PR (Precision-Recall)曲线下面的面积. 其中PR曲线的纵坐标为Precision, 横坐标为Recall. AP值越大, 平均准确率越高, PR曲线的面积越大, 算法的性能越好.

对于本文目标的评估, 因为所选取的样本为Du等[21]所公布的低表面亮度星系, 这些源不是基于光学巡天得到的, 而是基于中性氢巡天得到的. 因此在SDSS图像中存在一部分未被标记的目标样本, 而准确率、召回率、F1及AP值的假设条件是图像中所有低表面亮度星系样本都已被标注. 因此样本中实际正确的比率即召回率更能体现出其正确性, AP值其次, 准确率与F1也能一定程度上验证算法的性能.

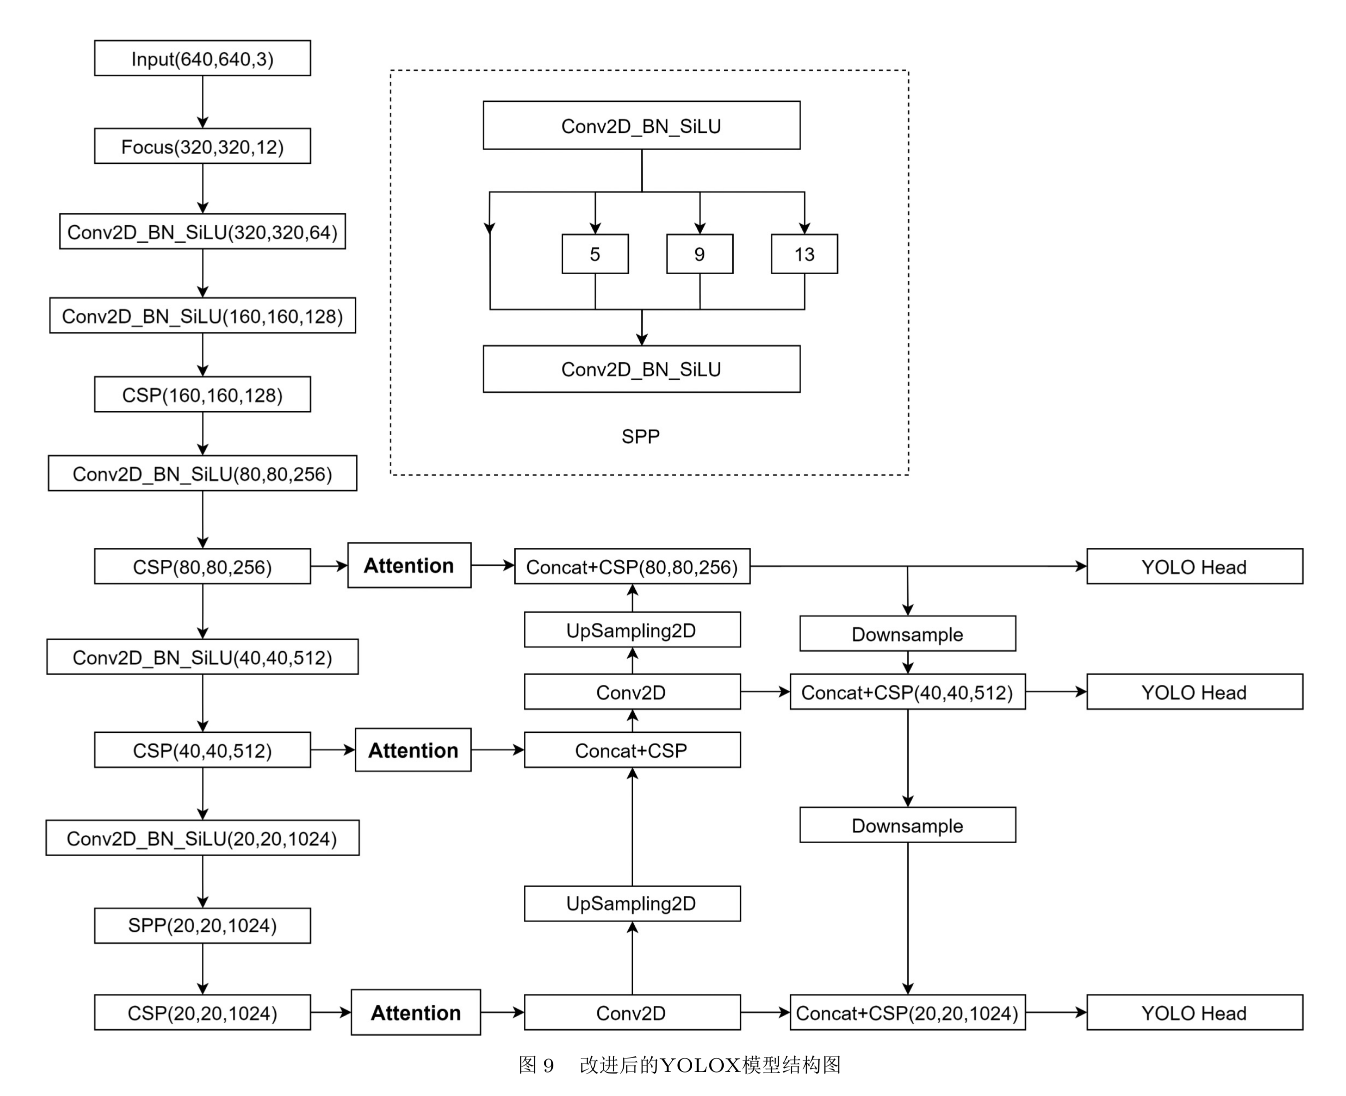


图 9 改进后的YOLOX模型结构图

Fig. 9 Improved YOLOX model structure diagram

4.2 实验参数设置及实验环境

DCGAN模型扩充数据集的实验中所使用的数据为96 × 96像素的单目标图像, 卷积通道设置为64, batch_size设置为64; 模型使用余弦退火衰减学习率, 模型的最大学习率设置为0.002, 最小学习率设置为最大学习率的0.01; 优化器使用Adam, 优化器内部参数momentum设置为0.5; 模型为从零开始训练, 共进行2000轮次的迭代.

目标检测算法中的标签平滑数值设置为0.005以防止过拟合; 使用余弦退火衰减学习率, 模型的最大学习率设置为0.01, 最小学习率设置为最大学习率的0.01; 模型的batch_size设置为4, 并没有使用迁移学习. 优化器使用SGD的实验, 优化器内部momentum参数设置为0.937. Faster R-CNN的损失函数为分类损失即交叉熵损失函数和回归损失, YOLO系列的损失为位置回归损失、物体置信度损失和类别损失函数, 其中位置回归损失函数所使用的为CIOU (Complete Intersection Over Union)损失函数.

本文所使用的为天文图像, 其特征和其他数据集差距较大, 故5种流行目标检测算法实验皆从零开始训练. 参数设置调整完成后将数据集送入网络进行300轮次的迭代. 而所有改进算法实验中使

用YOLOX第200轮次的参数权重作为初始权重进行训练, 这样既不会造成过拟合, 又能节省实验时间和计算资源. 并分别再利用2.2节中的两种数据集进行300轮次的迭代. 实验环境如表2所示.

表 2 实验环境

Table 2 Experimental environment

Attribute	Attribute value
Pytorch version	1.7.1
Torchvision version	0.8.2
GPU	NVIDIA RTX 3080Ti
CPU	Intel (R) Xeon (R) E5-2640 v4 @2.40 GHz
Internal storage	16 GB
Operating environment	Windows10

4.3 实验结果

本文首先使用YOLOX算法对2048 × 1489 (原图)与640 × 640 (裁剪图)进行对比实验, 结果如表3所示. 原天文图像尺寸过大, 实验所使用时间大约是640 × 640裁剪图实验时间的两倍, 同时其实验结果无论是准确率、召回率、F1和AP值皆不如裁剪图, 640 × 640的裁剪图AP值已达到96.4%, 召回率也有95.05%. 图像尺寸过小也不方便应用于大规模的天文图像, 因此图像尺寸640 × 640时无论是从速度还是算法性能角度考虑皆是最优选择.

确定使用的图像尺寸后, 本文将Faster R-CNN[26]、CenterNet[29]、YOLOv4[41]、YOLOv5、YOLOX[31]5种流行的深度学习算法应用于低表面亮度星系自动搜寻的实验中. Faster R-CNN使用的是600 × 600像素的VOC格式的数据集, 其余算法使用的皆是640 × 640像素的VOC格式的数据集. 图10展示了这5种流行算法的PR曲线结果, 每个PR曲线图的顶部表示类别为LSBG的AP值. 表4展示了其具体的实验结果.

从表4中可以看出Faster R-CNN的召回率是最高的为96.85%, 但其多检出的样本为286个, 而这286个样本并不能确保其都为低表面亮度星系, 导致AP值偏低及PR曲线的面积(图10)过小. 综合分析对比, YOLOX无论是F1值还是AP值都是最高的, 其召回率为95.05%也较高. 故本文选择YOLOX算法作为基础算法进行了改进提升.

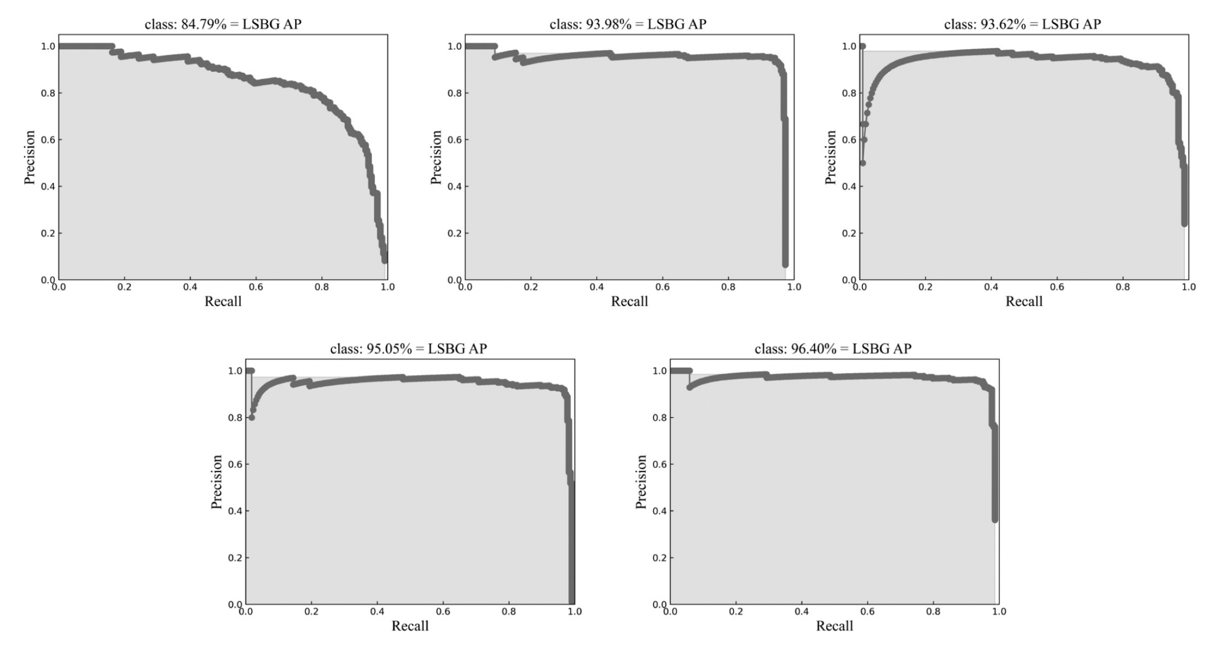


图 10 Faster R-CNN、CenterNet、YOLOv4、YOLOv5、YOLOX (由左向右)的PR曲线对比

Fig. 10 Comparison of PR curves of Faster R-CNN, CenterNet, YOLOv4, YOLOv5 and YOLOX (from left to right)

表 3 不同尺寸图像实验结果对比

Table 3 Comparison of experimental results of different size images

Algorithm	Imagesize	AP (%)	Precision (%)	Recall (%)	F1
YOLOX	2048 × 1489	88.29	84.00	85.14	0.85
YOLOX	640 × 640	96.40	95.48	95.05	0.95

表 4 流行目标检测算法实验结果对比

Table 4 Comparison of experimental results of popular target detection algorithms

Algorithm	Backbone	AP (%)	Precision (%)	Recall (%)	F1	DS[a]	UDS[b]	EDS[c]
Faster R-CNN	Resnet50	84.79	42.91	96.85	0.59	501	7	286
CenterNet	CSPDarknet	93.98	95.26	90.54	0.93	211	23	10
YOLOv4	CSPDarknet	93.62	95.73	70.72	0.81	164	65	7
YOLOv5	CSPDarknet	95.05	92.24	96.40	0.94	232	8	17
YOLOX	CSPDarknet	96.40	95.48	95.05	0.95	221	11	6

[a] Detected samples;

[b] Undetected samples;

[c] Excess detected samples.

4.4 算法改进对比实验

图11从左至右从上至下依次为YOLOX-SE (You Only Look Once version X-SE)、YOLOX-CS、YOLOX-ECA (You Only Look Once version X-ECA)、YOLOX-CA (You Only Look Once version X-CA)、YOLOX-CBA (You Only Look Once version X-CBA)、YOLOX-CR (You Only Look Once version X-CR)的PR曲线. 将所有改进算法实验结果放在一起进行对比. 如表5所示. YOLOX-SE为加入SE注意力机制模块且使用SGD优化器的YOLOX网络模型, YOLOX-CS为加入CBAM注意力机制模块且使用SGD优化器的YOLOX网络模型, YOLOX-ECA为加入ECA注意力机制模块且使用SGD优化器的YOLOX网络模型, YOLOX-CA为加入CA注意力机制模块且使用SGD优化器的YOLOX网络模型, YOLOX-CBA为加入CBAM注意力机制模块且使用Adam优化器的YOLOX网络模型, YOLOX-CR为加入CBAM注意力机制模块且使用RMSprop优化器的YOLOX网络模型.

由表5可得YOLOX-CS的综合效果最优, 算法对应实验结果中召回率为97.75%, AP值为97.83%, 皆为最高, 相比未改进前的模型召回率提高了2.7%, AP值提高了1.43%. YOLOX-CS算法未检出的样本只有5个, 且其召回率相对于Yi等[25]在关于低表面亮度星系的目标检测任务中的最新结果, 召回率提高了2.0%.

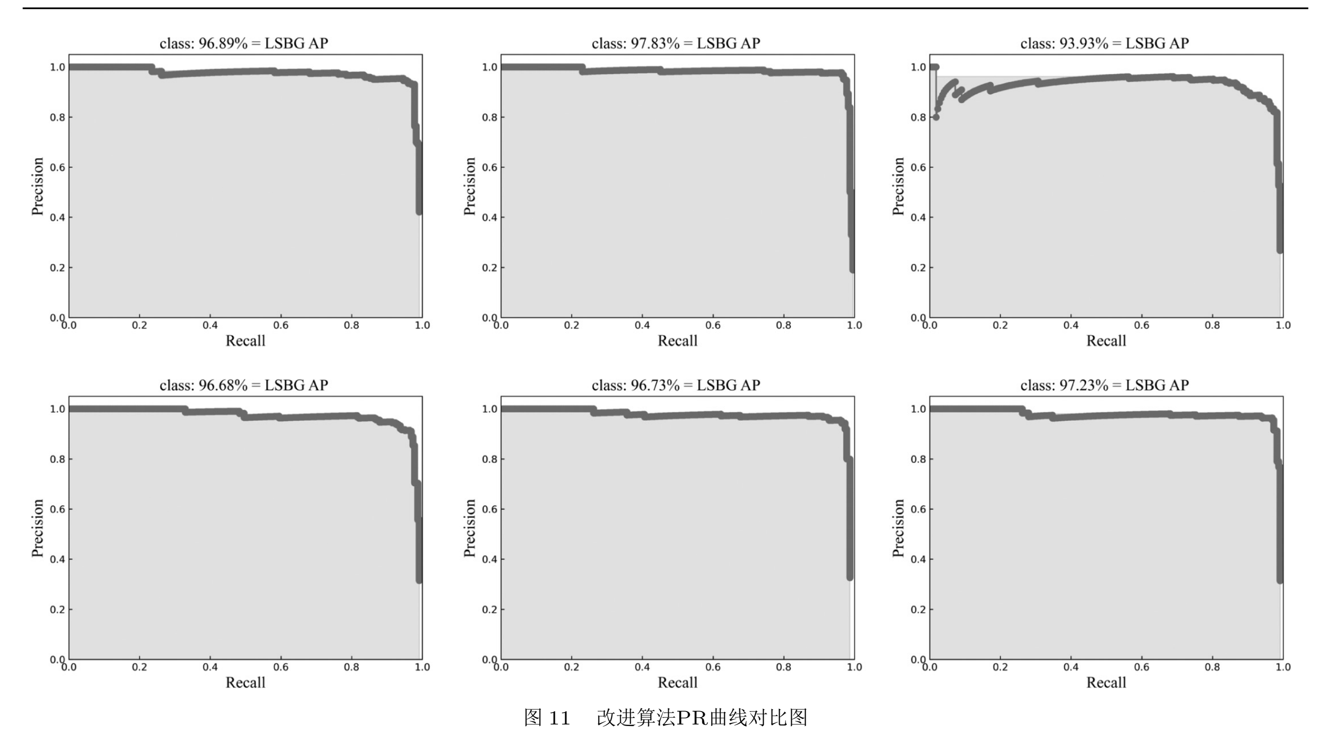


图 11 改进算法PR曲线对比图

Fig. 11 Comparison graph of improved algorithm PR curve

表 5 算法改进实验结果对比

Table 5 Comparison of experimental results of improved algorithm

Algorithm	Backbone	Optimizer	AP (%)	Precision (%)	Recall (%)	F1	DS	UDS	EDS
YOLOX-SE	CSPDarknet	SGD	96.89	95.43	94.14	0.95	219	13	8
YOLOX-CS	CSPDarknet	SGD	97.83	92.74	97.75	0.95	234	5	16
YOLOX-ECA	CSPDarknet	SGD	93.93	90	90.54	0.9	223	21	20
YOLOX-CA	CSPDarknet	SGD	96.68	93.64	92.79	0.93	220	17	14
YOLOX-CBA	CSPDarknet	Adam	96.73	93.51	97.30	0.95	231	6	14
YOLOX-CR	CSPDarknet	RMSprop	97.23	94.74	97.30	0.96	228	6	11

因此, 在检测低表面亮度星系的模型中加入CBAM且优化器为SGD的YOLOX算法是这些算法模型中效果最好的, 本文详细说明效果最好的YOLOX-CS所得到的具体实验结果, 表6及表7给出了未识别到的目标及多检测出的目标. 其中未检测到的原因是受周围源的影响和过暗, 多检测出的源的赤经和赤纬皆列在表7中.

表 6 YOLOX-CS中的未检样本

Table 6 Undetected samples in YOLOX-CS

Names of UDS	Right ascension	Declination	Cause not detected
002247-6-0185	188.50626	5.95278	The surrounding of target source is too bright
003836-1-0429	213.68124	10.07472	The target source is too dark
005087-4-0230	187.37042	27.61444	The center light around is too dark
003894-6-0090	217.3175	11.46333	The target source is too dark
003971-3-0156	222.05125	11.8175	The label is slightly offset by a nearby bright star

表 7 YOLOX-CS中的多检样本

Table 7 Excess detected samples in YOLOX-CS

Names of EDS	Right ascension	Declination	SDSS ObjID
002247-2-0110	177.226748418	4.134419836	1237655124469219850
002247-4-0085	173.532677792	5.049838084	1237655125541322921
003631-4-0286	159.491778002	13.691459043	1237661069789233531
003631-4-0286	Because of bright stars, one galaxy is identified as two		
003836-4-0589	237.897132315	8.014643243	1237661950277387118
003841-3-0142	186.108730462	7.113440595	1237661971186057661
003894-6-0090	217.338963335	11.504194109	1237662528456950022
003894-6-0090	Mistaking one galaxy for two		
003900-3-0054	129.757104647	25.128424237	1237664092899049479
003903-1-0319	229.123555534	6.203672333	1237662268611428698
003903-3-0184	Because of bright stars, one galaxy is identified as two		
004576-1-0190	141.231082939	25.645112236	1237667113870098760
004663-5-0055	The edge of a bright galaxy, detection error		
004674-6-0046	209.880843961	26.172342756	1237665550498136285
005116-5-0101	184.839624763	25.768601437	1237667448340414589
005308-2-0301	237.370024448	11.935897414	1237668271376630073

4.5 DCGAN扩充数据集的算法实验结果

在扩充后的数据集上的实验对比结果如表8所示, 使用的测试集和4.3节、4.4节所使用的测试集一致.

为验证使用DCGAN模型扩充数据集对于提升算法的有效性, 对扩充前后的结果进行比较分析, 即表5及表8. 扩充数据集上所有算法的召回率都达到99%以上, YOLOX-ECA和YOLOX-CA这两个算法的召回率达到了百分之百, 没有未检测出的目标; 所有算法的AP值都达到98%以上. 其中所有的算法最低的召回率依旧比未加入扩充数据集前最高的召回率高出1.35%. 对比结果说明, 使用DCGAN模型扩充数据集一定程度上提高了模型对低表面亮度星系目标检测的鲁棒性.

本文将扩充数据集训练后的算法权重在总数据集1106张图像上进行测试, 测试结果展示在

表9中, 所有算法的召回率都达到98%以上, 其中YOLOX-CA算法的召回率最高为98.73%, YOLOX-CS算法的AP值最高为98.64%. YOLOX-CS、YOLOX-ECA、YOLOX-CBA、YOLOX-CR算法的召回率仅次于YOLOX-CA. 所有的结果表明, 在天文图像处理领域, 引入注意力机制模块一定程度上提升了算法的性能. 其中YOLOX-CS算法在所有的实验中都表现出较好的效果.

4.6 YOLOX-CS算法的验证

为了验证此算法的有效性, 我们从文献[23]中报告的23970个低表面亮度星系随机抽取19996个, 大小皆为256 × 256, 图像中皆为单目标, 并将图像融合到640 × 640的图片中, 通过YOLOX-CS算法中进行检测识别, 其中16381个被准确识别出, 准确识别率为81.92%.

表 8 DCGAN扩充数据集下改进算法实验结果对比
Table 8 Comparison of experimental results of improved algorithms in DCGAN expanded dataset

Algorithm	Backbone	Optimizer	AP/%	Precision/%	Recall/%	F1	DS	UDS	EDS
YOLOX-SE	CSPDarknet	SGD	98.96	97.35	99.10	0.98	226	2	6
YOLOX-CS	CSPDarknet	SGD	98.94	96.92	99.10	0.98	227	2	7
YOLOX-ECA	CSPDarknet	SGD	98.77	96.52	100	0.98	230	0	8
YOLOX-CA	CSPDarknet	SGD	98.94	96.52	100	0.98	230	0	8
YOLOX-CBA	CSPDarknet	Adam	98.75	97.79	99.55	0.99	226	1	5
YOLOX-CR	CSPDarknet	RMSprop	98.64	94.83	99.10	0.97	232	2	12

表 9 DCGAN扩充数据集下改进算法实验结果对比—测试集1106
Table 9 Comparison of experimental results of improved algorithms in DCGAN expanded dataset—Test set 1106

Algorithm	Backbone	Optimizer	AP/%	Precision/%	Recall/%	F1	DS	UDS	EDS
YOLOX	CSPDarknet	SGD	98.34	96.19	98.19	0.97	1129	20	43
YOLOX-SE	CSPDarknet	SGD	98.42	96.36	98.10	0.97	1126	21	41
YOLOX-CS	CSPDarknet	SGD	98.64	96.63	98.37	0.97	1126	18	38
YOLOX-ECA	CSPDarknet	SGD	98.19	96.37	98.37	0.97	1129	18	41
YOLOX-CA	CSPDarknet	SGD	98.47	96.04	98.73	0.97	1137	14	45
YOLOX-CBA	CSPDarknet	Adam	98.46	96.20	98.37	0.97	1131	18	43
YOLOX-CR	CSPDarknet	RMSprop	97.77	93.48	98.46	0.96	1165	17	76

另外我们还验证了YOLOX-CS算法应用于搜寻SDSS原天文图像(2048 × 1489)中低表面亮度星系的性能, 在23970个目标中随机选取其中50个目标, 找到其所在的原天文图像, 将其放入训练好的YOLOX-CS算法中进行预测, 最终23个目标被准确找出; 在781个目标[22]中随机选取100个目标的天文图像, 最终65个目标被准确找出. 由于这两个数据集分别是暗能量巡天和Hyper Suprime-Cam (HSC)巡天所得到的星表, 而且这两个星表的低表面亮度星系的判断方式有所不同, 故和训练算法所用的数据集存在一定差异. 其中巨暗的低表面亮度星系很难被找出, 因为和天光背景很难进行区分.

5 LSBG候选体

最后, 本文使用YOLOX-CS算法在美国SDSS部分测光数据集上进行了实际搜寻检测. 我们选择了两个巡天观测区共1620张天文图像, 每张图像为2048 × 1489. SDSS DR16[27]对该数据进行了说明, 天区包含了目标的标准BOSS (Baryon Oscillation Spectroscopic Survey)选择区域, 在SDSS-III的14轮观测中被归类为"良好"观测的天区.

首先将每张图像的长调整尺寸到2166, 宽调整尺寸到1665, 然后裁剪为800 × 665大小的图像送入网络进行预测. 通过统计数据集中的1106张图像, 只有12张超过117 × 165像素, 有49张超过96 × 96像素. 考虑到有些目标会在图片的边缘, 为了保证搜寻到的低表面亮度星系能够更加全面, 对图像进行有重叠的裁剪, 横向重叠117个像素值, 纵向重叠165个像素值, 如图12所示.

将裁剪好的图像送入网络, 这样能够得到更加全面的低表面亮度星系候选体. 接下来算法预测出带框的低表面亮度星系候选体并得到锚框的上左下右的像素坐标. 由于所得到的为裁剪后图像的像素坐标, 故利用表10中的的公式将其转换为原天文图像2048 × 1489的像素坐标, 并结合对应图像的r波段的FITS文件, 利用Python中的坐标转换语句(pixel_to_world)将像素坐标转换为赤经和赤纬. 表10为裁剪后图像中候选体的像素坐标转换为原天文图像中像素坐标的公式, 00、01、02等代表图12中的图像位置编号, 根据候选体所在图像编号的公式对其坐标值进行转换, 最终得到原图中的坐标值.

图 12 原天文图像叠加裁剪方式

Fig. 12 Overlay clipping mode of original astronomical image

表 10 候选体在裁剪图像中的坐标转原图坐标计算公式

Table 10 Calculation formula for converting the coordinates of candidate in cropped images to the coordinates of original images

00, 01, 02 Formula for the x-axis	$(x_{\rm left} + x_{\rm right}) \div 2$
10, 11, 12 Formula for the x-axis	$683 + (x_{\rm left} + x_{\rm right}) \div 2$
20, 21, 22 Formula for the x-axis	$1366 + (x_{\rm left} + x_{\rm right}) \div 2$
00, 10, 20 Formula for the y-axis	$1489 - (y_{\rm top} + y_{\rm bottom}) \div 2$
01, 11, 21 Formula for the y-axis	$1489 - [500 + (y_{\rm top} + y_{\rm bottom}) \div 2]$
02, 12, 22 Formula for the y-axis	$1489 - [1000 + (y_{\rm top} + y_{\rm bottom}) \div 2]$

此时得到的赤经和赤纬并不是最终的精确值, 其存在一定的误差, 于是本文将转换得到的赤经和赤纬信息输入SDSS测光单张图像查询网站以找到星系的ObjID, 最后我们先将这些ObjID以CSV格式上传到My DB中, 在CasJobs服务器中编写结构化查询语言, 如表11. 该查询语句将PhotoObjAll星表、SpecObjAll星表和MyTable_cantry2 (包含ObjID信息的表格名称)表格信息交叉, 从PhotoObjAll星表和SpecObjAll星表中筛选出星系的基本信息、各个波段的星等、红移和星系的半径等, 之后以CSV格式输出星表. 最终得到的星系有868个, 其中有195个有光谱红移值, 另外673个没有光谱红移值的信息.

中心表面亮度的计算公式为:

$$\mu_0 = m + 2.5\lg(2\pi a^2) + 2.5\lg(b/a)\,. \qquad (4)$$

考虑了红移对面亮度的影响, 表面亮度计算公式最终变为:

$$\mu_0 = m + 2.5\lg(2\pi a^2) + 2.5\lg(b/a) - 10\lg(1+z)\,, \qquad (5)$$

其中m为星系的星等, a为星系盘的半长轴, b为星系盘的半短轴, z为红移值; 本文利用(4)式计算出这868个候选体的g、r、i波段的中心面亮度, 其中r波段的面亮度仅有3个数值是在20 mag · arcsec^{-2}以下, 有15个数值是在22 mag · arcsec^{-2}以下, 其余样本r波段面亮度皆在22–28 mag ·arcsec^{-2}之间. 利用(5)式计算得到有光谱红移值的195个候选体的r波段的中心面亮度, 其中r波段的面亮度仅有2个数值是在20 mag · arcsec^{-2}以下, 有10个22 mag · arcsec^{-2}以下的, 其余皆在22–26 mag · arcsec^{-2}之间.

根据(5)式, 红移值的增加会造成面亮度的降低, 因此本文对训练数据集中的红移值进行统计, 统计得出其中最高红移值为0.056396667, 计算其使r波段中心面亮度数值降低了约0.974%, 这表明在此数据集中红移值对中心面亮度的影响较小. 在考虑红移值的情况下中心面亮度的数值只会减小, 因此首先去除这868个候选体中r波段的面亮度数值在21.5 mag · arcsec^{-2}以下的源, 然后去除重复出现的源, 此时剩余771个候选体. 接下来将这771个候选体与天文数据库(网址为https://simbad.cds.unistra.fr/simbad/sim-fcoo)进行交叉比对后得到其中6个为已发布的低表面亮度星系. 最终剩余765个候选体, 其中157个有光谱红移值. 这157个有光谱红移值的候选体中红移值最大为0.3359404, 使得r波段面亮度数值降低了约4.933%, 除此之外只有6个候选体红移值在0.1–0.2之间, 其余皆在0.1以下. 图13展示了候选体中6个示例, 全部候选体的具体信息包括赤经、赤纬、星等值等展示在网址https:// nadc.china-vo.org/res/r101207/中.

表 11 输出ObjID相关信息的SQL查询语句

Table 11 SQL query statements that output ObjID information

SELECT
p.objID, p.run, p.camcol, p.field, p.obj, p.type,
p.ra, p.dec, p.u, p.g, p.r, p.i, p.z,
p.petroRad_i, p.petroRad_r, p.petroRad_g,
s.z, s.zErr, s.elodiez, s.class, s.specObjID, a.galID into mydb.MyTable
from dr16.PhotoObjAll as p, dr16.SpecObjAll as s, mydb.MyTable_cantry2 as a
WHERE p.objID = a.galID and p.objID = s.bestObjID

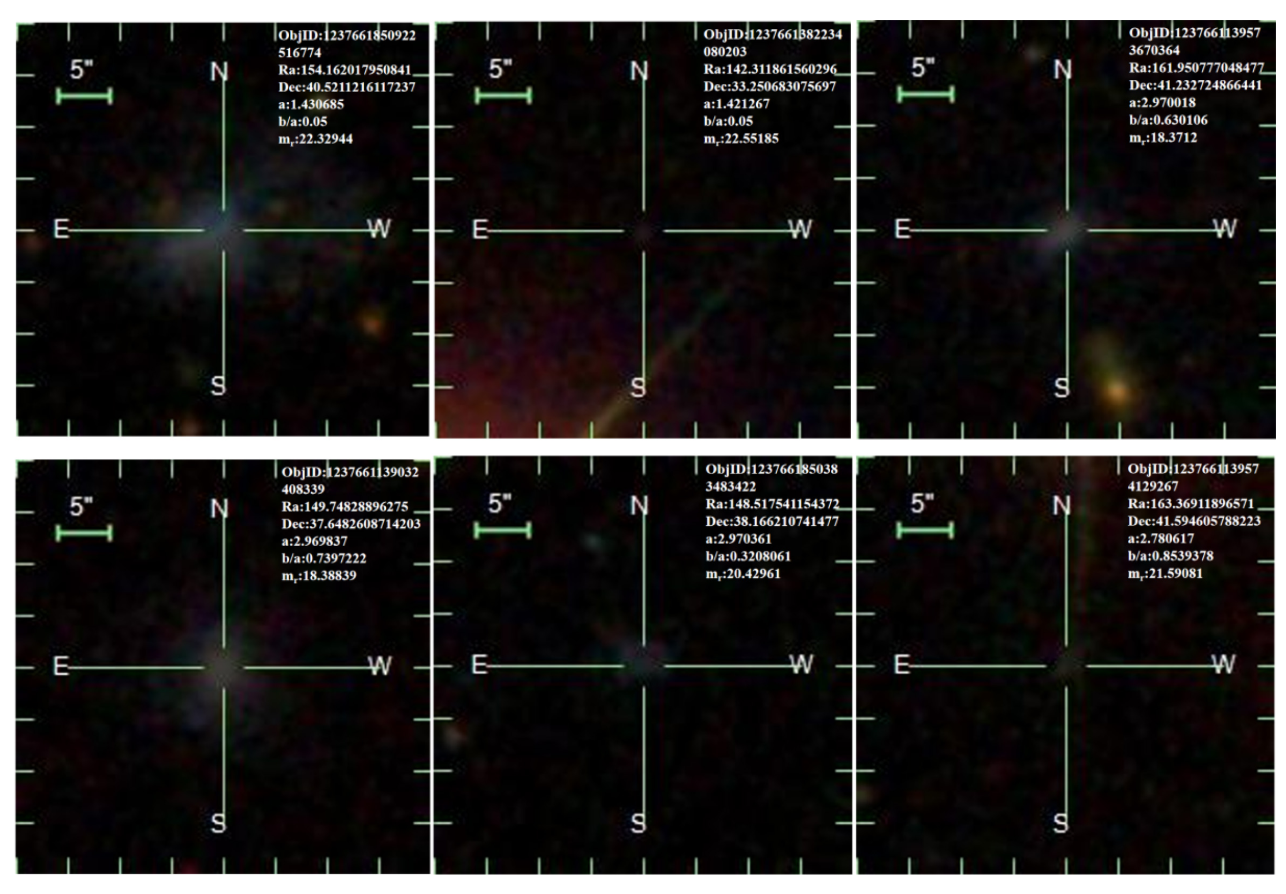


图 13 低表面亮度星系候选体示例

Fig. 13 Examples of Low Surface Brightness Galaxy candidates

6 结论

在天文大数据处理中深度学习表现出较为理想的效果, 未来深度学习将会更多地应用于处理天文大数据并能够解决更多的科学问题. 本文首先比较5种经典目标检测算法在检测低表面亮度星系任务上的性能, 从中得到最优算法—YOLOX, 再通过预训练、加入注意力机制、优化器选择以及DCGAN数据扩充等一系列改进, 得到一个更适用于检测低表面亮度星系的算法—YOLOX-CS. 该算法在AP值和召回率两个评估指标上具有最优值, 在未扩充数据集中的召回率达到97.75%, AP值达到97.83%, 未检测到的目标是最少的. 在DCGAN扩充的数据集的实验中, YOLOX-CS算法召回率达到99.10%, AP值达到98.94%. 本文利用YOLOX-CS算法在SDSS两个天区检测获得了765个新的低表面亮度星系的候选体.

参考文献

[1] 仲国虎, 梁艳春, 邓李才, 等. 天文学进展, 2010, 28: 255
[2] Zwicky F. Morphological Astronomy. Berlin: Springer, 1957: 88
[3] Freeman K C. ApJ, 1970, 160: 811
[4] McGaugh S S. MNRAS, 1996, 280: 337
[5] Impey C, Bothun G. ARA&A, 1997, 35: 267
[6] Impey C, Burkholder V, Sprayberry D. AJ, 2001, 122: 2341
[7] Ceccarelli L, Herrera-Camus R, Lambas D G, et al. MNRAS, 2012, 426: L6
[8] Courteau S. ApJS, 1996, 103: 363
[9] Adami C, Scheidegger R, Ulmer M, et al. A&A, 2006, 459: 679
[10] Jarrett T H. Proceedings of the 3rd EUROCONFERENCE on Near-Infrared Surveys Held at Meudon Observatory, France, June 19–20, 1998, 230: 239

[11] Impey C D, Sprayberry D, Irwin M J, et al. ApJS, 1996, 105: 209
[12] Bergvall N, Rnnback J, Masegosa J, et al. A&A, 1999, 341: 697
[13] Bell E F, Barnaby D, Bower R G, et al. MNRAS, 2000, 312: 470
[14] Jong R. A&A, 1996, 313: 377
[15] Galaz G, Dalcanton J J, Infante L, et al. AJ, 2002, 124: 3
[16] Kniazev A Y, Grebel E K, Pustilnik S A, et al. AJ, 2004, 127: 704
[17] O'Neil K, Bothun G D, Cornell M E. AJ, 1997, 113: 1212
[18] Ragaigne D M, Driel W V, O'Neil K, et al. A&A, 2003, 408: 67
[19] Zhong G H, Liang Y C, Liu F S, et al. MNRAS, 2008, 391: 986
[20] Haynes M P, Riccardo G, Martin A M, et al. AJ, 2011, 142: 170
[21] Du W, Wu H, Lam M I, et al. AJ, 2015, 149: 199
[22] Greco J P, Greene J E, Strauss M A, et al. ApJ, 2018, 857: 104
[23] Tanoglidis D, Drlica-Wagner A, Wei K, et al. ApJS, 2021, 252: 18
[24] Tanoglidis D, Iprijanovi A, Drlica-Wagner A, et al. A&C, 2021, 35: 100469
[25] Yi Z P, Li J, Du W, et al. MNRAS, 2022, 513: 3972
[26] Ren S, He K, Girshick R, et al. ITPAM, 2017, 39: 1137
[27] Ahumada R, Prieto C, Almeida A, et al. ApJS, 2020, 249: 3
[28] He Z, Qiu B, Luo A L, et al. MNRAS, 2021, 508: 2039
[29] Duan K, Bai S, Xie L, et al. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2019: 6568
[30] Radford A, Metz L, Chintala S. Proceedings of the 3rd International Conference on Learning Representations, San Diego: OpenReview.net, 2015
[31] Ge Z, Liu S, Wang F, et al. arXiv, 2021, 2107.08430
[32] Wang C Y, Liao H, Wu Y H, et al. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Seattle: IEEE, 2020: 1571
[33] He K, Zhang X, Ren S, et al. ITPAM, 2014, 37: 1904
[34] Liu S, Qi L, Qin H, et al. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18-23, 2018. Salt Lake City, UT. IEEE, 2018: 8759
[35] Ge Z, Liu S, Li Z, et al. Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville: IEEE, 2021: 303
[36] Jie H, Li S, Gang S, et al. ITPAM. 2020, 42: 2011
[37] Wang Q, Wu B, Zhu P, et al. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 11531
[38] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module. European Conference on Computer Vision. Cham: Springer, 2018: 3-19
[39] Hou Q, Zhou D, Feng J. Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville: IEEE, 2021: 13708
[40] Wibowo A, Wiryawan P W, Nuqoyati N I. JPCS, 2019, 1217: 12124.
[41] Bochkovskiy A, Wang C Y, Liao H. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020

YOLOX-CS: An Automatic Search Algorithm for Low Surface Brightness Galaxies

FENG Xue-qi[1] TU Liang-ping[1,2] ZHONG Zheng-di[1] LI Juan[1] LI Xin[1]

(1 School of Science, University Science and Technology Liaoning, Anshan 114051)
(2 School of Mathematics and Statistics, Minnan Normal University, Zhangzhou 363000)

Abstract The characteristics of Low Surface Brightness Galaxies (LSBGs) are very important for understanding the overall characteristics of galaxies. It is of great significance to search and expand the samples of low surface brightness galaxies by modern machine learning, especially deep learning algorithm. LSBGs are difficult to discern automatically and accurately with traditional methods because of their obscure features. However, deep learning does have the advantage of automatically identifying complex and effective features. To solve this problem, an algorithm named You Only Look Once version X-CS (YOLOX-CS) is proposed to search LSBG in large sample sky survey. Firstly, five classical target detection

algorithms are compared through experiments and the optimal YOLOX algorithm is selected as the basic algorithm. Then, the YOLOX-CS framework is constructed by combining different attention mechanisms and different optimizers. The data set uses images from the Sloan Digital Sky Survey (SDSS), labelled from LSBG in the α.40-SDSS DR7 (the cross coverage area of 40% HI Arecibo Legacy Fast ALFA Survey and SDSS Data Release7) survey. Due to the small number of samples in this data set, Deep Convolutional Generative Adversarial Networks (DCGAN) model is used to expand the experimental test data. After comparing with a series of target detection algorithms, YOLOX-CS has a good test result in searching LSBG recall rate and Average Precision (AP) value in two data sets before and after expansion. The recall rate and AP value in the test set without expansion data set reach 97.75% and 97.83%, respectively. In the expanded data set of DCGAN model, under the same test set, the recall rate reaches 99.10% and the AP value reaches 98.94%, which proves that the algorithm has excellent performance in LSBG search. Finally, the algorithm is applied to SDSS photometric data, and 765 LSBG candidates are obtained.

Key words galaxies: general, methods: data analysis, methods: target detection, techniques: image processing